




<https://rbgeomorfologia.org.br/>
ISSN 2236-5664



Artigo de Pesquisa

Modelagem com redes neurais artificiais da suscetibilidade a movimentos de massa do município de Joinville, SC, Brasil

Landslide Susceptibility Modeling Using Artificial Neural Networks in the Municipality of Joinville, southern Brazil

Renato Ribeiro Mendonça ¹, Guilherme Garcia de Oliveira ² e Carlos Gustavo Tornquist ³

¹ Universidade Federal do Rio Grande do Sul -UFRGS, Programa de Pós Graduação em Sensoriamento Remoto-PPGSR, Porto Alegre, Brasil. renatormendonca@gmail.com.

ORCID: <https://orcid.org/0009-0008-1038-7698>

² Universidade Federal do Rio Grande do Sul -UFRGS, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia - CEPSSRM, Porto Alegre, Brasil. g.g.oliveira10@gmail.com.

ORCID: <https://orcid.org/0000-0003-4197-5704>

³ Universidade Federal do Rio Grande do Sul -UFRGS, Faculdade de Agronomia, Departamento de Solos, Brasil. carlos.tornquist@ufrgs.br.

ORCID: <https://orcid.org/0000-0002-5715-0654>

Recebido: 29/11/2023; Aceito: 17/12/2024; Publicado: 29/12/2024

Resumo: A avaliação da suscetibilidade a movimentos de massa (SMM) em um município é crucial na prevenção de desastres. Redes Neurais Artificiais (RNA) provaram ser eficazes nessa análise. Este estudo modelou a SMM em Joinville, Santa Catarina, usando RNA. O município tem histórico significativo desses eventos, permitindo um levantamento de áreas de ocorrência (OC) através do mapeamento de cicatrizes em imagens de satélite. Para áreas de não ocorrência (NO), foi utilizado um buffer de 1 km, subtraindo as OC. Pontos aleatórios foram gerados a cada 10 m, com valor 1 para OC e 0 para NO. As variáveis explicativas foram divididas em três grupos: (i) morfométricas, (ii) distâncias horizontais para estradas e estruturas e (iii) dados cartográficos geoambientais. Cinco configurações de RNA foram testadas. Na validação, métricas como área sob a curva ROC (AUC) e acurácia global (ACC) foram usadas, com a melhor modelagem apresentando AUC de 0,90 e ACC de 0,84. Essa configuração usou todas as variáveis explicativas, exceto uso e cobertura da terra, causando um leve viés na RNA, devido ao predomínio de cicatrizes em áreas florestais no inventário. A geologia desempenhou um papel crucial na determinação da suscetibilidade.

Palavras-chave: Prevenção de Desastres, Aprendizado de Máquina, Suscetibilidade a Movimentos de Massa.

Abstract: Assessing mass movement susceptibility (MMS) in a municipality is crucial for disaster prevention, and Artificial Neural Networks (ANNs) have proven effective in this analysis. This study aimed to model MMS in the municipality of Joinville, Santa Catarina state, southern Brazil, using ANNs. The municipality has a significant history of such events, allowing for an inventory of occurrence areas (OC) through scar mapping on satellite images. For non-occurrence areas (NO), a 1 km radius buffer was used, subtracting OC from it. Random points were generated at 10 m intervals, with a value of 1 for OC and 0 for NO. The explanatory variables were divided into three groups: (i) morphometric variables, (ii) horizontal distances to roads and structural lineaments, and (iii) geo-environmental cartographic databases. Five ANN configurations were tested. Validation employed metrics such as area under the ROC curve (AUC) and overall accuracy (ACC), with the best modeling yielding an AUC of 0.90 and ACC of 0.84. This result utilized all explanatory variables except land use and cover, which caused a slight bias in the ANN due to the predominance of scars in forested areas in the inventory. Geology played a crucial role in determining susceptibility.

Keywords: Disaster Prevention, Machine Learning, Landslide Susceptibility.

1. Introdução

Uma forma eficaz de mitigar desastres decorrentes de movimentos de massa (MM) e subsidiar tecnicamente a tomada de decisão do poder público para o uso e ocupação municipal de maneira sustentável é o estudo da suscetibilidade a esses eventos extremos. Entende-se por suscetibilidade a movimentos de massa como a propensão das encostas e vertentes em desenvolver processos de MM e correlatos (SOBREIRA; SOUZA, 2012), (BRESSANI; COSTA, 2013), (MINISTÉRIO DAS CIDADES, 2013). Diversos modelos de MM têm sido criados, com abordagens baseadas em física (modelos conceituais), análise heurística e estatística (LUO; LIU, 2017). Cada uma dessas abordagens oferece uma maneira única de avaliar a suscetibilidade a MM, considerando fatores específicos e complexos.

Por exemplo, o Serviço Geológico do Brasil (CPRM) e o Instituto de Pesquisas Tecnológicas (IPT) utilizam modelos quantitativos associados a uma análise heurística, obtendo-os pela relação de densidade de cicatrizes presentes em um determinado município associada à densidade de lineamentos estruturais e declividade do terreno (BITAR, 2014). Este modelo de suscetibilidade foi desenvolvido para responder a dois axiomas: ampla aplicabilidade no diverso território brasileiro e obtenção de forma expedita, a fim de subsidiar um programa governamental contínuo de mapeamento de cartas de suscetibilidade cujos primeiros trabalhos datam de 2012. Um problema desse método é a influência da interpretação do modelador na qualidade do modelo final, uma vez que os dados de entrada, como lineamentos geoestruturais, dependem da interpretação do modelo digital de elevação pelo próprio modelador (LAMBERTY; KEPPEL FILHO; NORONHA, 2015).

Uma maneira de obter uma avaliação robusta da suscetibilidade de uma região seria o uso de técnicas de aprendizado de máquina (AM) e Inteligência Artificial (IA). Com o rápido avanço das tecnologias de sensoriamento remoto nos últimos anos, é possível coletar uma grande quantidade de dados relacionados a MM de forma mais rápida e eficiente. Muitos pesquisadores têm utilizado tais dados para modelar a suscetibilidade a MM por metodologias envolvendo IA (PASCALÉ et al., 2013; ZHU et al., 2018; EMANI, 2020; LUCCHESI; OLIVEIRA; PEDROLLO, 2021). Esses métodos podem analisar a complexa relação entre a suscetibilidade a MM e os fatores que a afetam a partir de grandes conjuntos de dados (ZHU et al., 2018). Como mencionado por Lucchese, Oliveira e Pedrollo (2021), a Inteligência Artificial envolve a teoria e o desenvolvimento de sistemas de computadores que simulam a inteligência humana. De acordo com Zhu et al. (2018), várias pesquisas têm utilizado IA para modelar a suscetibilidade a MM (GÓMEZ; KAVZOGLU, 2004; PRADHAN; LEE, 2010; DOU et al., 2015; YAO et al., 2022), uma vez que esses métodos são capazes de assimilar com maior robustez grandes conjuntos de dados de entrada e cicatrizes de movimentos de massa, produzindo mapas de áreas suscetíveis com métricas de desempenho (por exemplo, acurácia global) superiores aos métodos convencionais de modelagem.

Dentre as diversas abordagens de técnicas de AM, as Redes Neurais Artificiais (RNA) destacam-se por sua flexibilidade em relação à escala dos dados e pela capacidade de incorporar tanto variáveis qualitativas quanto quantitativas em suas análises (KAWABATA; BANDIBAS, 2009), e independentemente da forma de distribuição de dados (WANG et al., 1995). Entre os trabalhos que apresentam resultados satisfatórios em ajustar uma RNA para suscetibilidade de movimento de massa, Pradhan e Lee (2010) conduziram um estudo em Cameron Highlands, Malásia, usando um inventário de 324 cicatrizes em uma área de 293 km², com atributos de terreno provenientes de um MDE (modelo digital de elevação) de 10 m. Eles utilizaram o algoritmo de RNA retropropagativo com 10 entradas, 22 neurônios na camada oculta e 2 saídas. Os resultados mostraram que a declividade foi a variável que mais influenciou o modelo final e o desempenho com AUC (área sob a curva ROC - *Receiver Operating Characteristic*) de 0,83. Quevedo et al. (2019a) modelaram áreas suscetíveis a MM na Bacia Hidrográfica do Rio Rolante, a nordeste do estado do Rio Grande do Sul. Eles usaram o mapeamento de 308 cicatrizes de MM ocorridas na cabeceira da bacia durante um evento extremo de precipitação em 2017. A partir desses dados, foram extraídas informações morfométricas do modelo digital de terreno para treinamento da RNA, validando-se os resultados com AUC superior a 0,9. Ullah (2022) propôs uma abordagem para mapeamento de suscetibilidade de múltiplos processos geodinâmicos usando três diferentes abordagens: RNA, Regressão Logística e K-vizinhos mais próximos (KNN). A RNA foi treinada com dados históricos de enxurradas, fluxo de detritos e deslizamentos planares rasos, obtidos a partir de imagens de satélite no distrito de Shangla, Paquistão. Utilizou-se diversos parâmetros geomorfométricos, além de mapas geológicos e de uso e cobertura da terra como dados

amostrais. A RNA apresentou melhores resultados de desempenho do modelo, em comparação com os demais métodos, chegando a valores de AUC de 0,98 para enxurradas, AUC de 0,94 para deslizamentos e AUC de 0,98 para fluxo de detritos.

A habilidade de extrapolação é uma importante característica da RNA, especialmente quando se trata de determinar a suscetibilidade de movimentos de massa em áreas com pouca ou nenhuma ocorrência de MM. De acordo com o trabalho de Gameiro (2020), os modelos de RNA são empíricos e podem ter seu desempenho prejudicado ao extrapolarem-se o domínio numérico do treinamento. No entanto, o autor destaca que a extrapolação espacial em áreas de geomorfologia homogênea pode gerar resultados satisfatórios, especialmente quando os atributos do terreno são semelhantes entre as áreas de treinamento e teste. Além disso, a distância no processo de amostragem para não ocorrência é um fator considerável para se obter melhores resultados, permitindo que a RNA distinga, com melhor desempenho, as áreas suscetíveis das não suscetíveis. O autor realizou em seu trabalho amostragem de 5 bacias diferentes na região da Serra Geral para treinamento de uma RNA para cada conjunto de amostragem e destacou como a amostragem influencia o mapeamento de áreas suscetíveis a deslizamentos com RNA, ressaltando a importância das variáveis de declividade, fator LS e elevação. A acurácia dos modelos aumentou com buffers maiores para amostras de não ocorrência, e a representatividade das amostras influenciou na capacidade de extrapolação.

Neste trabalho, temos o objetivo de estudar a suscetibilidade de Movimentos de Massa usando RNAs no município de Joinville, localizado no estado de Santa Catarina, Sul do Brasil. Este município possui um histórico significativo de eventos de movimentos de massa ao longo das últimas décadas, sendo o evento de maior magnitude registrado em novembro de 2008 (ODEBRECHT et al., 2017). Devido a esse histórico de ocorrências, o município de Joinville possui um importante acervo de cicatrizes de MM, que podem ser explorados para a construção de um modelo de RNA e a geração de um mapa preciso de suscetibilidade a MM.

2. Materiais e Métodos

Para desenvolver um modelo de suscetibilidade a MM utilizando RNA, é preciso realizar a amostragem de áreas onde ocorreram MM, bem como de áreas onde não houve ocorrência desses eventos. De acordo com Wang et al. (2019), ao identificar essas áreas, é possível relacioná-las com atributos de terreno associadas aos MM e, em seguida, extrapolar os resultados para outras áreas com base na suposição de que os MM futuros ocorrerão em ambientes semelhantes aos dos MM anteriores. Portanto, para o objetivo deste trabalho, foram mapeadas e identificadas as cicatrizes de deslizamento no perímetro da área de estudo. Após a coleta das cicatrizes, essas áreas foram relacionadas com dados sobre a morfologia do terreno e seu substrato, que afetam diretamente a estabilidade. Por fim, esses dados foram utilizados para treinar uma rede neural eficiente com o objetivo de criar um modelo de suscetibilidade do terreno a MM. O fluxograma de preparação dos dados de amostragem, processamento, validação e apresentação do mapa de suscetibilidade é apresentado na Figura 1.

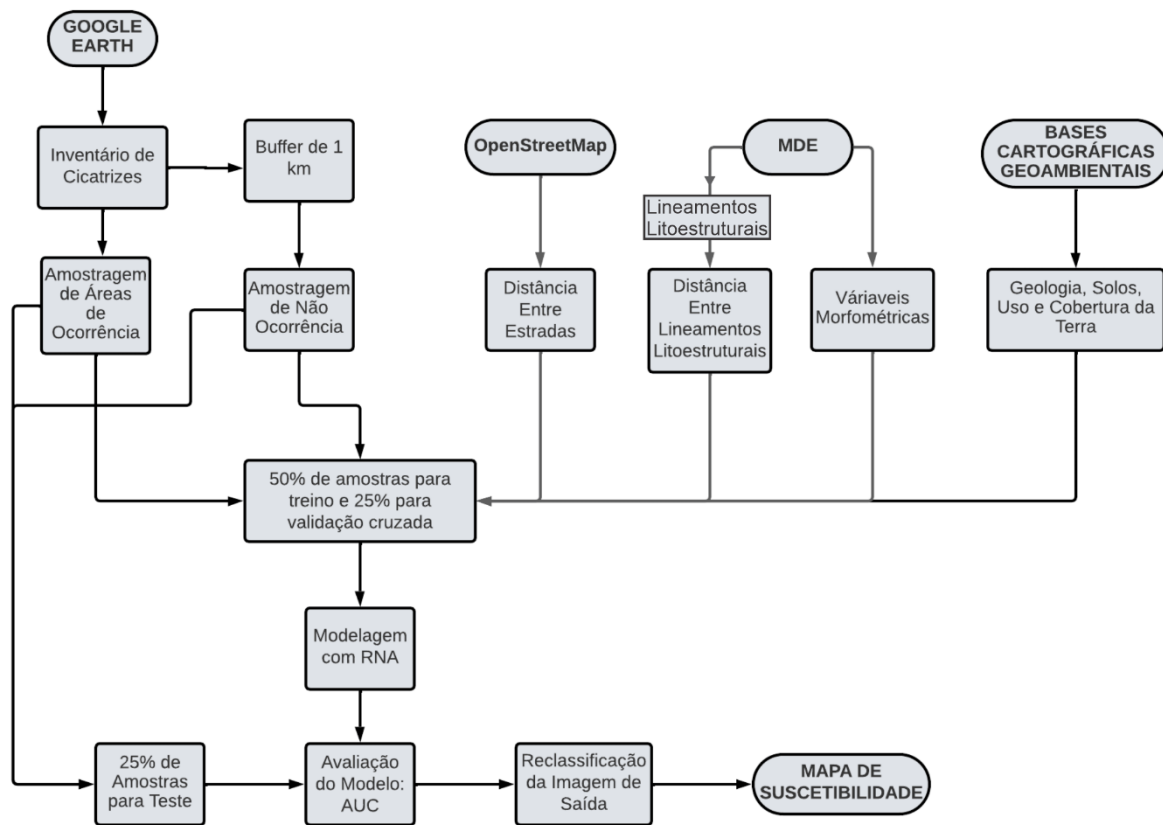


Figura 1. Fluxograma metodológico para obtenção do modelo de suscetibilidade. Fonte: Organizado pelo autor.

2.1. Área de Estudo

O estudo de suscetibilidade a movimentos de massa (SMM) foi conduzido no município de Joinville, Santa Catarina (Figura 1). Joinville está localizada ao norte do estado e possui a maior população. Além de ser o polo econômico da mesorregião norte do estado, sua área urbana está em expansão (IBGE 2022). Segundo Odebrecht et al. (2017), o litoral de Santa Catarina registrou valores extremos de precipitação entre setembro e novembro de 2008, acumulando mais de 1000 mm de chuva, com o ápice nos dias 22 e 23 de novembro. Durante esse período, ocorreram mais de 800 processos de MM no município; porém, apesar do número elevado, a incidência de MM na área urbanizada foi mínima, resultando apenas em danos materiais e sem vítimas fatais.

Na Figura 2, são apresentadas as cicatrizes reconhecidas nas imagens históricas do software Google Earth Pro. Para uma melhor amostragem e ampliação do acervo de cicatrizes, com a finalidade de diversificar o conjunto de amostras e enriquecer o conhecimento prévio do modelo de RNA, além da possibilidade de empregar o mesmo modelo para municípios adjacentes, optou-se por extrapolar o limite municipal. Incluíram-se, além da bacia do rio Cubatão, que compreende a área norte do município, a bacia do rio Itapocu e seus dois afluentes, os rios Itapocuzinho e Jaraguá. Considerou-se também a parte sul da serra do Quiriri, ao norte do município, pois esta possui um importante acervo de cicatrizes de MM. Assim, a somatória dessas áreas compreende a Área de Amostragem (AA), conforme pode ser visto na Figura 2.

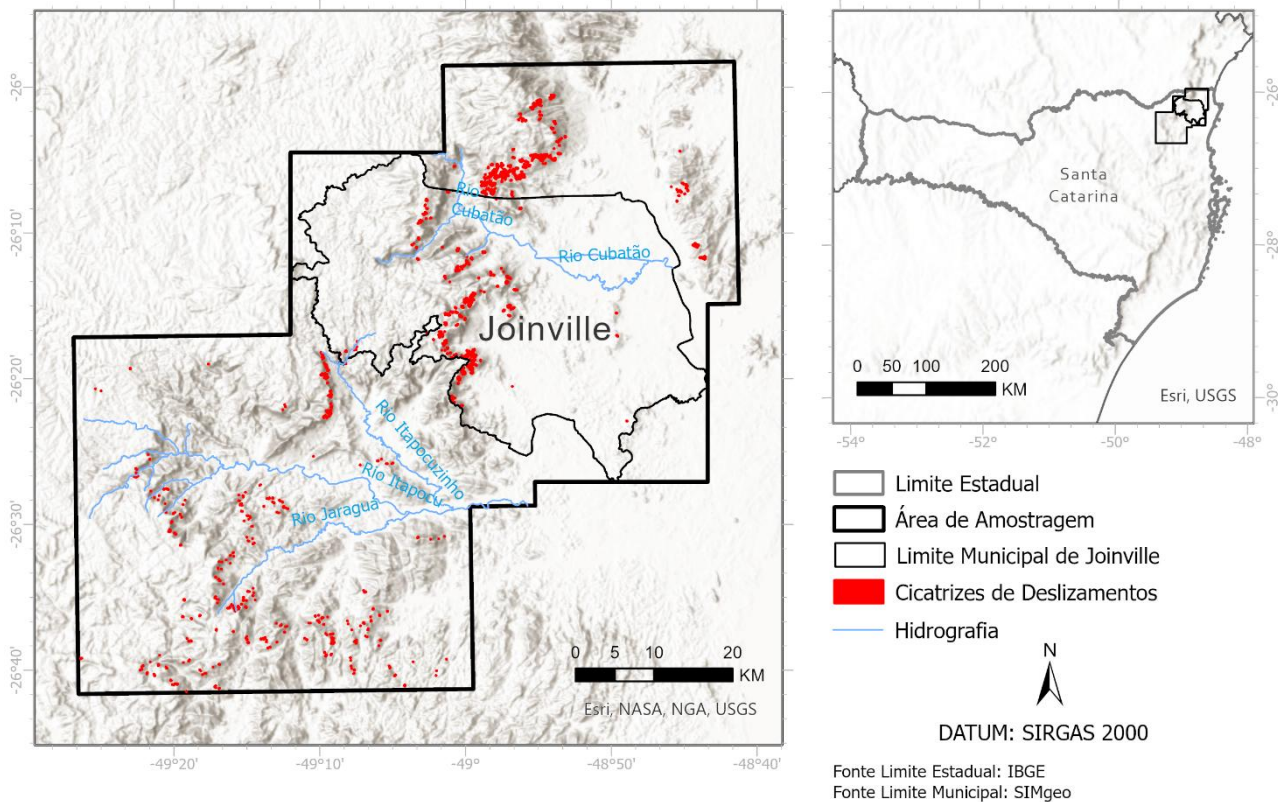


Figura 2. Área de amostragem de movimentos de massa para o estudo. Fonte: Organizado pelo autor.

2.2. Amostragem de ocorrências e não ocorrências

O mapeamento do inventário de cicatrizes de MM foi realizado por meio de interpretação visual e vetorização, utilizando imagens de sensoriamento remoto pelo software Google Earth PRO, conforme feito nos trabalhos de Pham et al. (2017) e Wang et al. (2019). Foram reconhecidas e mapeadas 784 cicatrizes de MM, tanto a área de deflagração quanto a área de atingimento dos MM, no período de 2009 a 2018. Também foi mapeada a área de atingimento dos MM, dentro do perímetro da AA. Após delimitar as áreas de ocorrência, foram gerados pontos aleatórios dentro dessas áreas através do software ArcGIS PRO 3.01 (ESRI, 2023), com espaçamento mínimo de 10 metros entre eles, totalizando 20.480 pontos amostrais de ocorrência.

Segundo Lucchese, Oliveira e Pedrollo (2021), uma das considerações relacionadas à amostragem de locais onde não ocorreram MM é a definição de uma distância máxima em relação às cicatrizes desses movimentos. Essa determinação é de grande importância, pois visa evitar uma coleta de amostras restrita a áreas próximas às cicatrizes. Uma abordagem mais abrangente na amostragem de locais sem ocorrência é eficaz para compreender os fatores que influenciaram os movimentos de massa nas cicatrizes, em contraste com as áreas circundantes. Adicionalmente, essa abordagem considera a premissa de que a chuva, que pode desencadear eventos de movimentos de massa, exibe uma variabilidade espacial significativa. No entanto, recomendar a seleção de áreas muito distantes das cicatrizes pode ser inadequado, uma vez que não há garantia de que ambas as áreas tenham experimentado a mesma quantidade de precipitação que ocorreu na região das cicatrizes.

Portanto, para a geração do inventário de áreas de não ocorrência, foi gerado um buffer com raio de 1 km a partir das cicatrizes, excluindo-se as áreas das cicatrizes, o que impede a coleta de amostras de não ocorrência nessas áreas. As áreas de ocorrência de deslizamento e não ocorrência são exemplificadas na Figura 3. Em seguida, foram gerados pontos aleatórios no perímetro dessa área de não ocorrência, com o mesmo espaçamento das áreas de ocorrência, limitando-se ao mesmo número de 20.480 pontos amostrais, mantendo uma relação paritária e balanceada (1:1) entre os dois grupos amostrais, evitando-se enviesamento do modelo de RNA. Por fim, as amostras foram classificadas com valor 1 para os pontos de ocorrência e valor 0 para os pontos de não ocorrência.

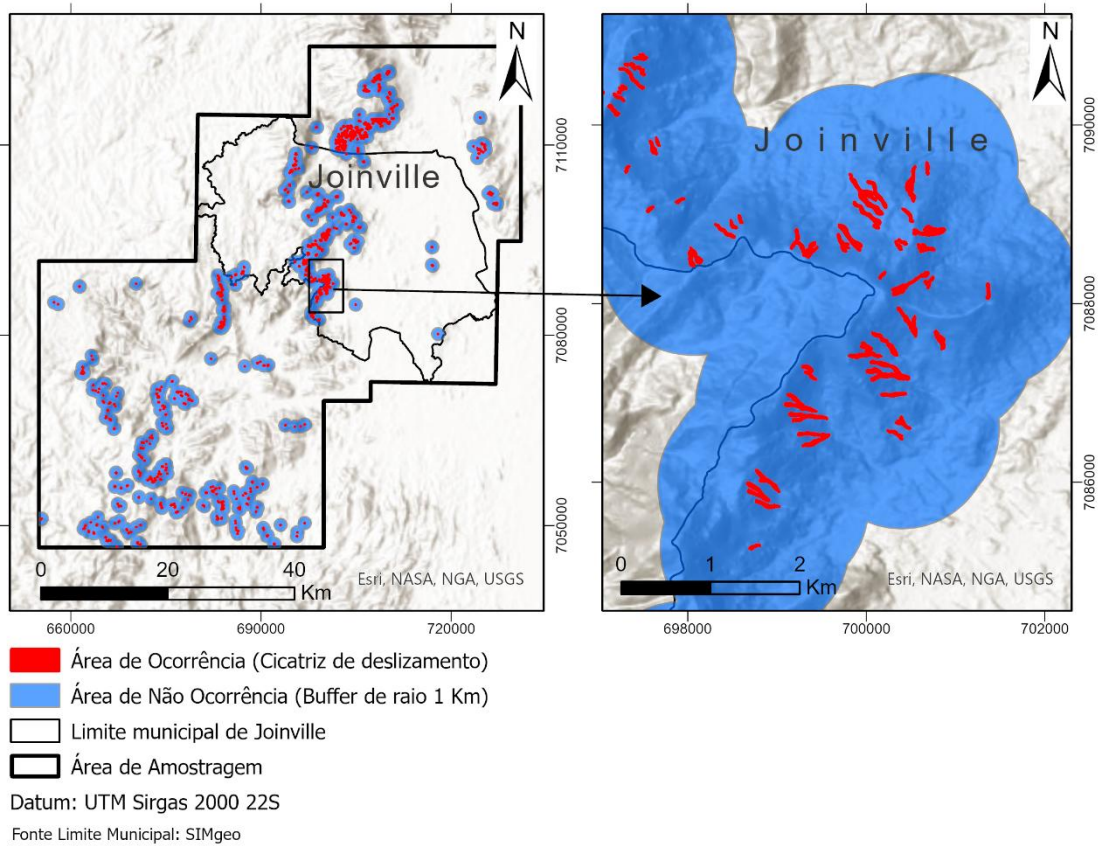


Figura 3. Áreas de ocorrência de deslizamento (cicatrices) e não ocorrência (buffer de 1 km de raio). Fonte: Organizado pelo autor.

2.3. Conjunto de dados

As pesquisas de Reichenbach et al. (2018) destacam diversas variáveis que ajudam a explicar a ocorrência de MM, tornando a seleção criteriosa de variáveis para criar um modelo de suscetibilidade confiável e robusto. Nesse contexto, foram selecionados dados de entrada para treinar a rede que, além de influenciar movimentos de massa em geral, estivessem em sintonia com a geomorfologia e a natureza do substrato da AA. Os parâmetros selecionados foram categorizados em três conjuntos: aqueles referentes à morfometria do terreno, os relacionados às distâncias entre lineamentos estruturais e estradas, e aqueles derivados de fontes cartográficas com características qualitativas de cunho geoambiental. Essa abordagem abrangente visa garantir um modelo mais acurado e robusto de suscetibilidade a MM para a região específica sob investigação. As variáveis selecionadas são apresentadas na Tabela 1.

Tabela 1. Variáveis explicativas utilizados para modelagem de suscetibilidade a movimentos de massa de Joinville-SC.

Variável	Fonte
Altitude (ALT)	MDE SDS 1m.
Orientação de Face de Vertente (OFV)	MDE SDS 1m.
Declividade (DECL)	MDE SDS 1m.
Distância Horizontal de Estradas (DHE)	Open Street Map (2023)
Distância Horizontal de Lineamentos Litoestruturais (DHLL)	Interpretação do MDE SDS 1m.
Índice Topográfico de Umidade (ITU)	MDE SDS 1m.
Geologia	Mapa Geológico do Estado de Santa Catarina - CPRM (2014).
Uso e Cobertura da Terra	MAPBIOMAS (2021)
Pedologia	IBGE (2021)

O processamento para a obtenção dos dados de natureza morfométrica para o modelo utilizou como base o Modelo Digital de Elevação (MDE) fornecido pela Secretaria de Estado do Desenvolvimento Econômico Sustentável (SDS) do Governo do Estado de Santa Catarina. Este MDE possui resolução espacial e altimétrica de 1 metro (SIGSC, 2017) e foi adquirido por meio de aerolevanteamento. Esses dados estão disponíveis gratuitamente no portal SIGSC. Para um melhor desempenho computacional, este MDE foi reamostrado para um tamanho de pixel de 5 metros. Os processamentos para a obtenção desta base de dados foram executados no software ArcGIS PRO 3.01 (ESRI, 2023). Para garantir que os dados morfométricos estejam na mesma escala, foi criada uma rede de pontos equidistantes a cada 5 metros, tanto vertical quanto horizontalmente. Em seguida, foram extraídos os valores de cada variável morfométrica para cada ponto. Com esses valores, foi gerado um raster para cada variável utilizando a ferramenta *Topo to Raster* no software ArcGIS PRO 3.01.

2.3.1. Variáveis morfométricas

As variáveis morfométricas escolhidas para o estudo são: Altimetria (ALT), Declividade (DECL), Orientação de Face de Vertente (OFV) e Índice Topográfico de Umidade (ITU). Tais variáveis são demonstradas na Figura 4. Os dados de ALT são obtidos a partir do MDE, onde cada pixel representa a altitude de um ponto. A área de estudo apresenta um intervalo altimétrico de 0 a 1540 metros. A DECL do terreno é expressa em graus e está diretamente relacionada com a estabilidade do terreno. A OFV, ou Aspect, tem valores em graus no intervalo de 0 a 360. Alguns estudos indicam que a OFV exerce uma influência indireta na estabilidade das encostas, devido aos efeitos da precipitação, do vento e da radiação solar que atingem determinada face da encosta, resultando em condições distintas de umidade, intemperismo e vegetação predominante no terreno (BRAGAGNOLO et al., 2020 citando CHEN et al., 2017; DING et al., 2017; TIEN BUI et al., 2017).

Conforme Beven & Kirkby (1979), o ITU ou *Topographic Wetness Index (TWI)* avalia o escoamento de águas superficiais e o acúmulo de umidade no terreno. Ele é definido em função logarítmica da declividade e da área de contribuição, conforme equação 1,

$$ITU = \ln \left(\frac{A_s}{\tan B} \right) \quad (1)$$

Em que: A_s é a área de contribuição e B é a declividade do terreno. O índice topográfico de umidade tem o propósito de representar o controle topográfico da umidade do solo. De acordo com Tien Bui et al. (2017), a suscetibilidade a MM pode ser estimada como uma função da relação entre os efeitos topográficos na resposta hidrológica de uma área, atuando diretamente sobre a pressão de poros no solo.

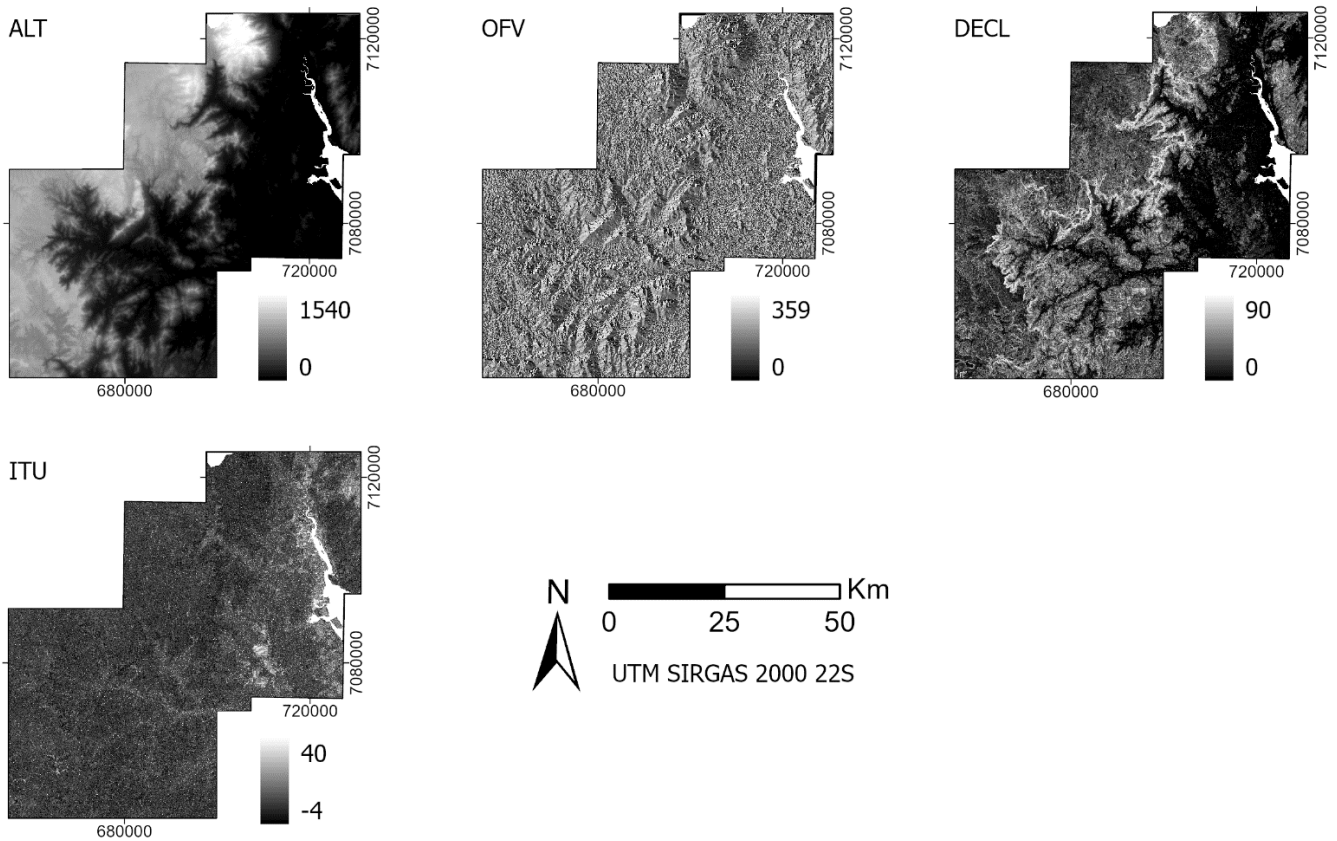


Figura 4. Variáveis morfométricas selecionadas para estudo: Altimetria (ALT); direção de face da vertente (DFV), declividade do terreno (DECL) e índice topográfico de umidade (ITU). Fonte: Organizado pelo autor.

2.3.2. Distância horizontal entre lineamentos estruturais e estradas.

No estudo, foram utilizadas duas variáveis de distância: a Distância Horizontal de Estradas (DHE) e a Distância Horizontal de Lineamentos Litoestruturais (DHLL) (Figura 5). A DHE está relacionada ao grau de intervenção humana no terreno, podendo induzir deslizamentos em taludes cortados por estradas. Para a obtenção da DHE, foi utilizado o OpenStreetMap por meio do plugin *OSMDownloader* no software QGIS 3.28, seguido do cálculo da distância euclidiana. Por outro lado, a DHLL está associada ao grau de fraturamento do substrato rochoso, decorrente de deformações geológicas estruturais do tipo rúptil. A obtenção da DHLL envolveu a delimitação de vales destacados por estruturas lineares no Modelo Digital de Elevação (MDE), seguida da vetorização e conversão em imagem, utilizando também o cálculo da distância euclidiana.




Figura 5. Variáveis de Distância Horizontal de Estradas (DHE) e Distância Horizontal de Lineamento Litoestruturais (DHLL) para a Área de Amostragem (AA). Fonte: Organizado pelo autor.

2.3.3. Base de dados cartográficos geoambientais

A geologia é amplamente utilizada em modelos de suscetibilidade (WANG et al., 2019). Diferentes tipos de litologia influenciam os vários níveis de suscetibilidade (CHEN et al., 2017), uma vez que essa variável é responsável por definir a resistência ao cisalhamento dos materiais que compõem as encostas, desempenhando um papel crucial na determinação de sua condição de estabilidade (ZÊZERE et al., 2017). Para este estudo, foi utilizada a litologia extraída do Mapa Geológico do Estado de Santa Catarina, fornecido pelo Serviço Geológico do Brasil – CPRM (2014), disponível na escala de 1:500.000. Apesar de ter uma escala menor que a utilizada para variáveis morfométricas, optou-se por este dado devido à sua disponibilidade em toda a AA e por ser de natureza qualitativa. As unidades geológicas foram reinterpretadas como unidades litológicas para simplificar a entrada na RNA.

De acordo com Pham et al. (2016), o estudo do Uso e Cobertura da Terra é relevante para identificar áreas suscetíveis a MM, especialmente considerando a presença e a remoção da vegetação. Para este propósito, utilizou-se a base de dados do Projeto de Mapeamento Anual da Cobertura e Uso do Solo do Brasil (MAPBIOMAS), coleção 7.1, correspondente ao ano de 2021, com escala de 1:100.000. As classes de uso e cobertura da terra foram simplificadas para o Nível 1, ou seja, agrupadas de acordo com o tipo de formação. A base pedológica empregada no estudo foi fornecida pelo Instituto Brasileiro de Geografia e Estatística – IBGE (2021), com escala de 1:250.000, e agrupada de acordo com a textura de cada pedotipo. A Figura 6 demonstra os dados qualitativos usados como entrada para o treinamento da RNA.

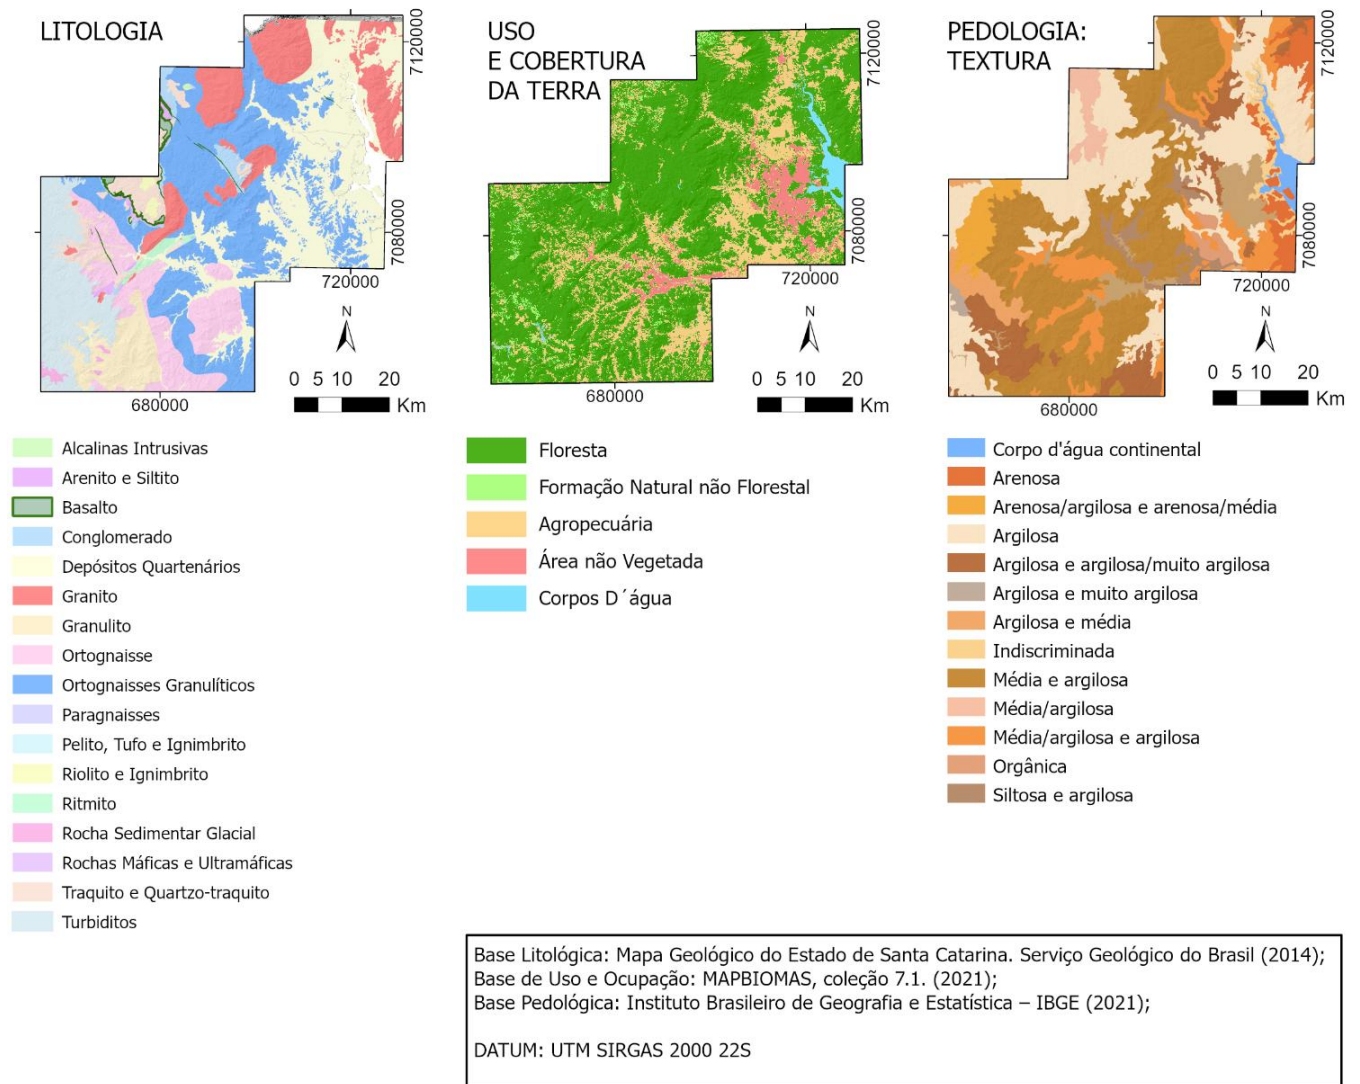


Figura 6. Base de dados geoambientais e qualitativos para área de estudo. Fonte: Organizado pelo autor.

Uma vez que as classes dos mapas qualitativos de litologia, pedologia e uso e cobertura da terra não possuem uma relação de ordem entre si, adotou-se uma codificação do tipo *one-hot encoding* em que cada classe foi descrita como uma combinação de imagens com código 0 ou 1. Para as 17 classes de litologia, foram definidas 5 imagens binárias, que combinadas permitem que a RNA diferencie todas as classes. Para as 4 classes de uso e cobertura da terra, foram definidas 2 imagens binárias, enquanto para as 14 classes de tipos de solo, foram definidas 4 imagens binárias.

Finalmente, uma vez que o conjunto de dados de entrada para a RNA foi definido, procedeu-se à extração dos valores das variáveis para cada ponto de amostragem, tanto para casos de ocorrência quanto para casos de não ocorrência. Essa extração foi realizada por meio do software ArcGIS PRO 3.01 (ESRI, 2023). Além disso, conduziu-se uma análise exploratória dos dados utilizando gráficos do tipo *boxplot*, com o intuito de investigar a relação entre as variáveis explicativas e a variável dependente.

2.4. Redes Neurais Artificiais

Para este estudo, foi empregado um modelo de RNA do tipo Perceptron de Multicamadas, também conhecido como *Multilayer Perceptron* (MLP), seguindo o método retropropagativo com múltiplas camadas proposto por Rumelhart et al. (1986). Utilizamos o software MATLAB 2021 para o treinamento da rede, aplicando a Regra Delta (WIDROW; HOFF, 1960) para atualização dos pesos sinápticos, por meio de um script desenvolvido pelos autores. Além disso, adotamos a técnica de série paralela de validação cruzada para evitar o superajustamento da rede. Os valores das variáveis foram normalizados por meio de transformações lineares, e a função de ativação utilizada nos neurônios foi a sigmoide.

Foram realizados testes com cinco configurações de RNAs. A primeira configuração incluiu todos os dados de entrada da base proposta (RNA1). As outras configurações excluíram os dados qualitativos individualmente: uma RNA sem o dado de geologia (RNA2), outra sem o dado de uso e cobertura da terra (RNA3), e uma terceira sem o dado de pedologia (RNA4). Por fim, foi testada uma RNA apenas com dados morfométricos e distâncias (RNA5) para avaliar o impacto desses dados no resultado. O número máximo de iterações, ou inicializações de cada RNA, foi fixado em 5, e o número de ciclos de aprendizagem foi estabelecido em 50.000 para todas as configurações. O número de neurônios para treinamento da RNA seguiu a equação $2x+1$, onde x é o número de variáveis de entrada.

As amostras foram divididas em três séries: 50% para treinamento, 25% para teste e 25% para validação cruzada. Para validar o modelo, foram utilizadas a acurácia global (ACC) e a métrica Área Sob a Curva (AUC), conforme DeLong et al. (1988). As validações seguiram o mesmo procedimento adotado por Lucchese et al. (2021) e Oliveira et al. (2019). A acurácia global é calculada pela seguinte equação:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

Em que: TP é o índice de verdadeiros positivos, TN é o índice de verdadeiros negativos, FP é o índice de falsos positivos e FN é o índice de falsos negativos.

Já a AUC é a área sob a curva ROC, que expressa a relação entre a Taxa de Verdadeiros Positivos (TVP) e a Taxa de Falsos Positivos (TFP). As amostras foram divididas em diversos grupos de duas classes por meio de diferentes limiares. Para cada divisão, calculamos a TVP e a TFP, construindo, assim, a curva ROC (FAWCETT, 2006). As relações são dadas pelas seguintes equações:

$$TVP = \frac{TP}{(TP + FN)} \quad (3)$$

e

$$TFP = \frac{FP}{(FP + TN)} \quad (4)$$

Em que: TP é o índice de verdadeiros Positivos, TN é o índice de verdadeiros negativos, FP é índice de falsos positivos, FN é índice de falsos negativos.

O resultado do modelo é obtido na forma de imagem contendo valores no intervalo de 0 a 1. Esses valores foram reclassificados em 5 classes por estatística de quebras naturais e cada classe relacionadas a níveis de suscetibilidade a MM.

3. Resultados e discussão

Para uma análise estatística inicial, foram plotadas as amostras de ocorrência e não ocorrência para cada medida morfométrica em gráficos do tipo boxplot, conforme mostrado na Figura 7. A análise topográfica revelou que a maioria dos movimentos ocorre em altitudes entre 400 e 750 m, com mediana igual a 539,86 m e desvio padrão igual a 226,01 m. Porém, diferentemente dos estudos de Kawata e Bandibas (2009) e Chen et al. (2017), que identificaram que este era um atributo preponderante, em Joinville observa-se a sobreposição de dados de ocorrência e não ocorrência, tornando-se difícil determinar uma altitude preferencial para ocorrência de MM. Esta discrepância pode estar relacionada ao relevo do município de Joinville, onde, apesar de se observar grande amplitude de ALT, a morfologia do terreno é composta por formas aplainadas separadas por uma grande escarpa de planalto, escarpa esta onde se concentram o maior número de ocorrências de MM no município.

A análise da declividade do terreno natural (DECL) demonstrou que ângulos acima de 30° são suscetíveis a MM; a mediana da declividade é calculada em 35,74° e o desvio padrão é de 10,46. A variável DECL é reconhecida em vários estudos como um dos fatores mais significativamente associados à ocorrência de movimentos de massa (PRADHAN; LEE, 2010; OLIVEIRA et al., 2018; QUEVEDO et al., 2019b). Da mesma forma, a variável DECL se destaca como a que mais efetivamente diferencia os conjuntos amostrais de ocorrência e não ocorrência no município de Joinville, em comparação com as outras variáveis. Portanto, acredita-se que esta seja a variável explicativa do modelo de MM em estudo aqui. Importante ressaltar que a maioria das áreas acima de 30° de declividade em Joinville está associada à escarpa de planalto na direção NE-SW, ou seja, esta tendência estrutural parece influenciar a suscetibilidade. Em concordância com a informação anterior, a análise da OFV indicou que a maioria dos MM ocorre em áreas pertencentes ao segundo quadrante, logo, com direção de movimento para o sentido SE.

Os dados de DHE indicam que os MM são mais frequentes à medida que se afastam do eixo das principais estradas. Em contraste, observa-se que os movimentos têm uma ocorrência preferencial próxima aos lineamentos estruturais, sugerindo que a principal natureza dos movimentos de massa nessa região é influenciada por fatores geológicos e geomorfológicos locais. Além disso, a presença de atividades humanas parece ter uma contribuição reduzida na indução desses MM dentro do espaço amostral analisado. A concentração de baixos valores de ITU indica a reduzida retenção de umidade topográfica nos locais de ocorrência. Entretanto, as medianas dos índices de ITU de ocorrência e não ocorrência são muito próximas, não permitindo fazer uma correlação direta.

Na Figura 8, é apresentada a relação entre deslizamentos e dados geoambientais. É notável que a maioria significativa das cicatrizes ocorre em litotipos relacionados a granitos, ortognaisses, granulitos e ortognaisses granulíticos. No que se refere ao uso e cobertura do solo, os deslizamentos estão predominantemente associados à classe de Floresta. Além disso, a textura do solo predominante nas áreas de deslizamento está relacionada principalmente a solos de composição média e argilosa, presumivelmente provenientes das rochas ígneas e metamórficas de alto grau. De maneira geral, as ocorrências de MM em Joinville estão associadas a áreas vegetadas, com perfil raso de intemperismo, derivados de rochas graníticas e metamórficas, com declividades em média de 35,74°.

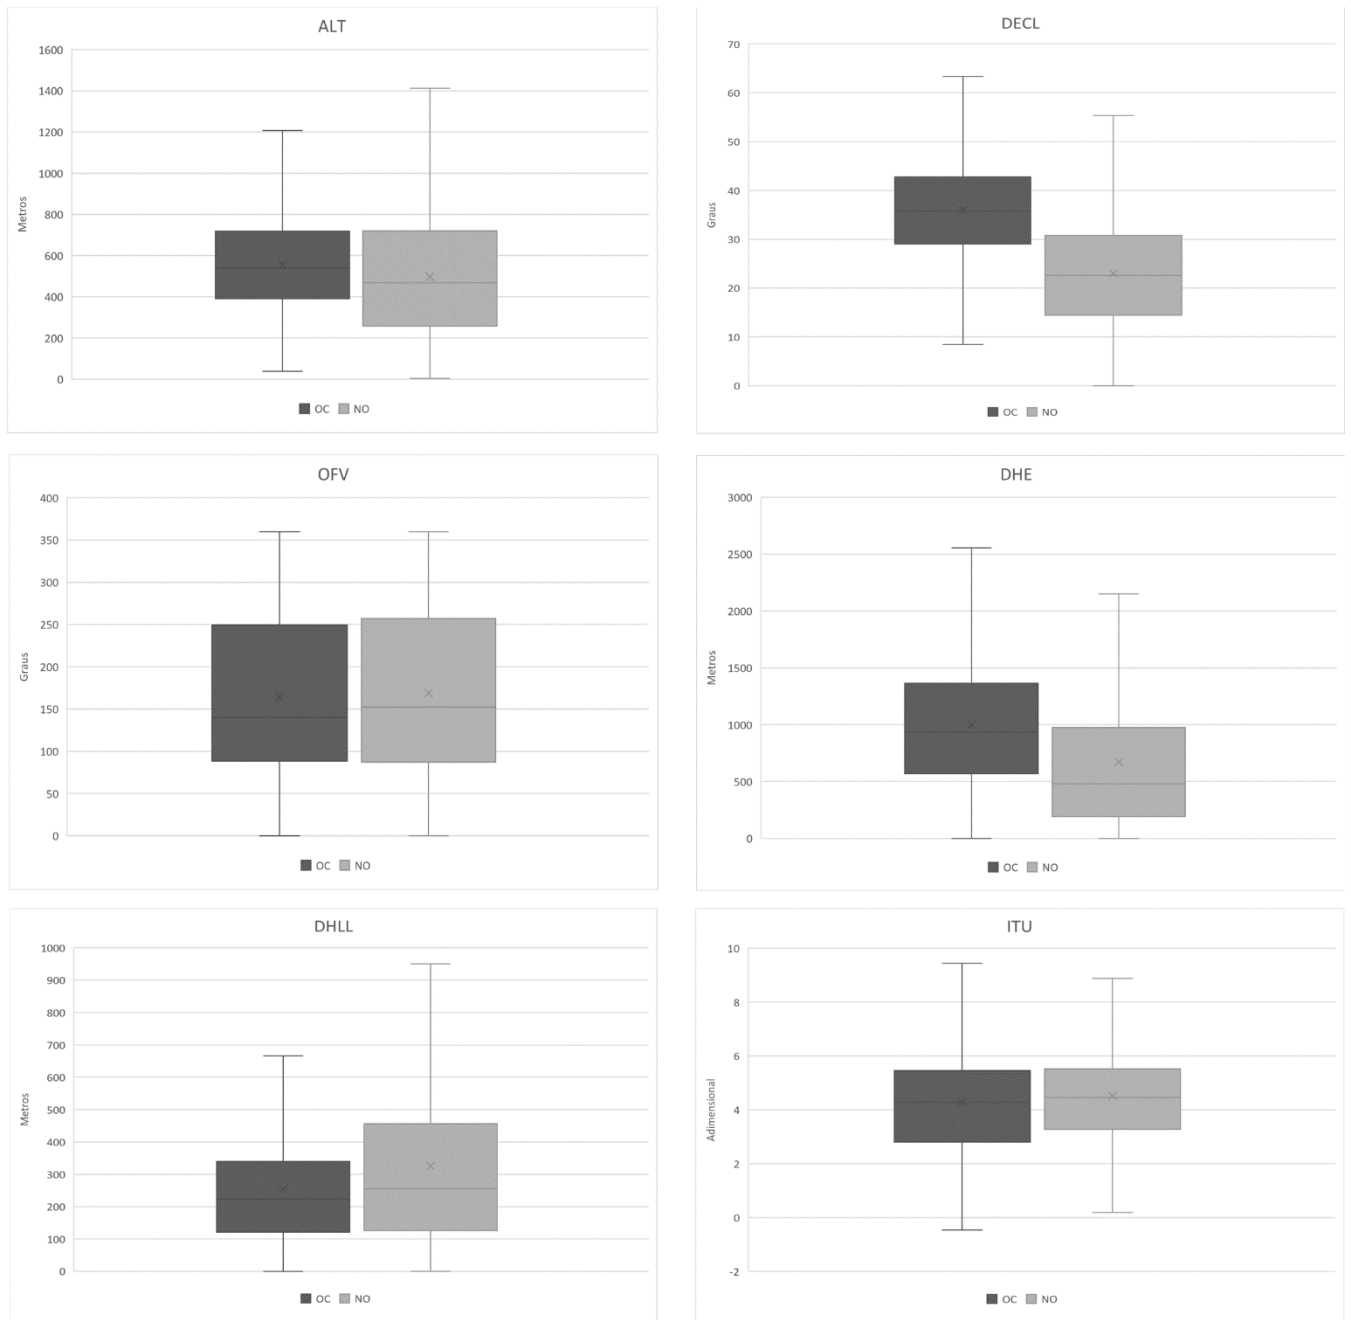


Figura 7. Gráficos Boxplot referente a cada dado morfológicos dividido em áreas de ocorrência (OC) e não ocorrência (NO). Legenda: ALT é a altitude em metros; DECL é a declividade em graus; OFV é a orientação de face de vertente em graus; DHE é a distância horizontal de estradas em metros; DHLL é a distância horizontal de lineamentos Litoestruturais em metros e o ITU é o índice topográfico de umidade (adimensional). Fonte: Organizado pelo autor.




Figura 8 – Número de Ocorrências de deslizamentos frente aos dados cartográficos de natureza geoambiental: (a) Número de ocorrências x Litologia; (b) Número de Ocorrências x Uso e Cobertura da terra e (c) Pedologia: Classe Textural.

Os valores de AUC e ACC, obtidos nas cinco simulações de RNA, são apresentados na Tabela 2. O objetivo foi selecionar modelos com acurácia superior a 80% (PRADHAN; LEE., 2010; DOU et al., 2015) critério que todos os modelos superaram. Apesar das simulações deste trabalho apresentarem resultados de acurácia aproximados, a simulação RNA 3 obteve a melhor performance, com valores de AUC de 0,9 e de ACC próximo de 84% para o município de Joinville. Estes resultados são próximos dos que Quevedo et al. (2019) encontrou em seu modelo para a Bacia Hidrográfica do Rio Rolante (AUC > 0,9) e Gameiro (2020) encontrou para modelos produzidos na região ao sul, central e nordeste do estado de Santa Catarina (AUC entre 0,87 e 0,93). Esta relação de paridade é importante, visto que as regiões têm condicionantes geomorfológicos muito semelhantes. Os produtos de saída calculados pela RNA são demonstrados na Figura 9, explicitando as principais diferenças dos modelos calculados pela RNA. A Figura 10 mostra a área total de cada classe de suscetibilidade para as cinco simulações de RNA.

Tabela 2. Métrica de desempenho dos modelos para os diversos conjuntos amostrais.

		RNA 1	RNA 2	RNA 3	RNA 4	RNA 5
AUC	Treinamento	0,901	0,873	0,909	0,903	0,849
	Teste	0,882	0,854	0,887	0,875	0,836
	Validação Cruzada	0,887	0,866	0,893	0,885	0,846
ACC	Treinamento	0,848	0,807	0,856	0,843	0,782
	Teste	0,823	0,789	0,829	0,814	0,768
	Validação Cruzada	0,828	0,803	0,838	0,822	0,776

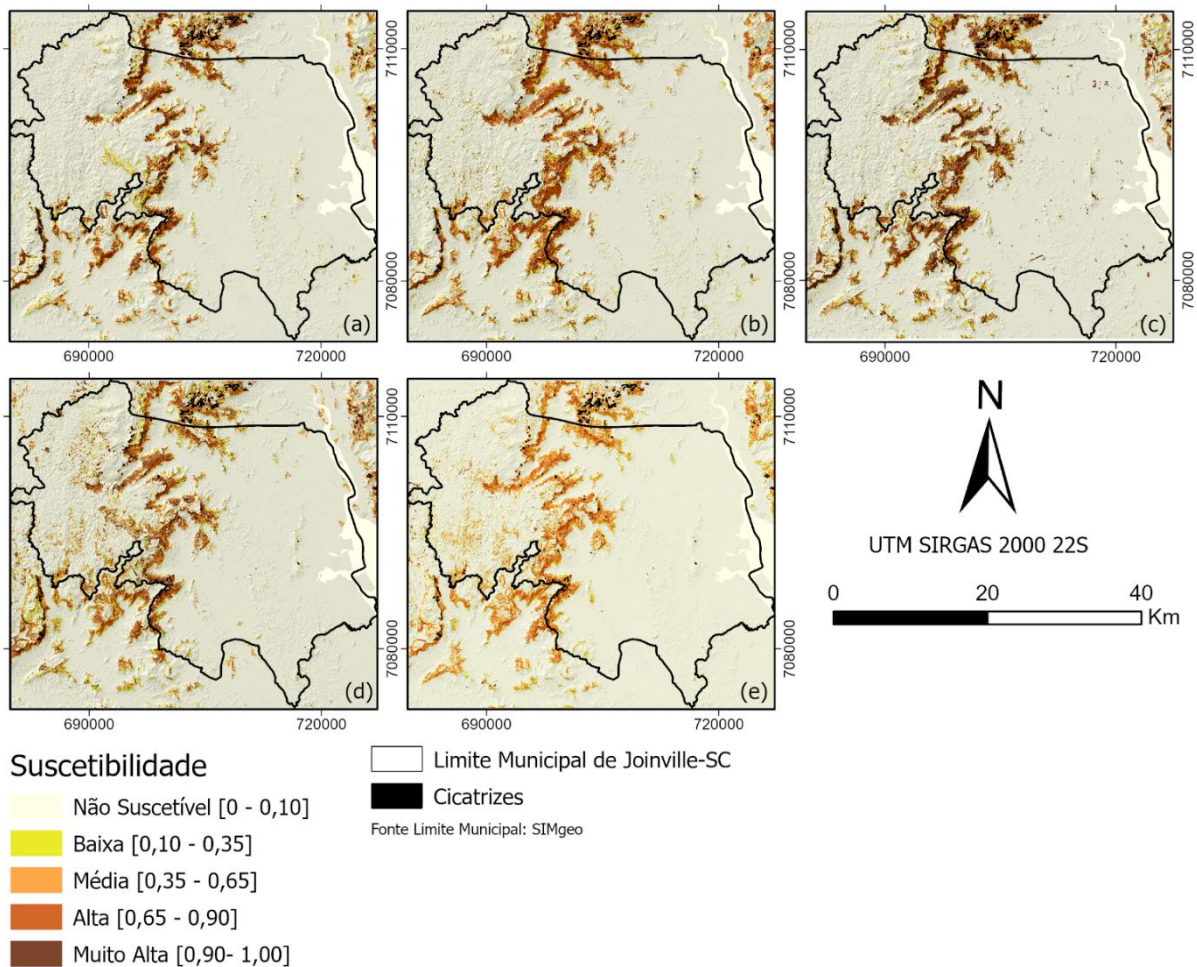


Figura 9. Mapas de saída calculados pela RNA para cada conjunto amostral – (a) RNA1: Todos os dados de entrada para o modelo; (b) RNA 2: Sem dado de Litologia; (c) RNA 3: Sem o dado de uso e ocupação da terra, possuindo melhores resultados de acurácia; (d) RNA 4: Sem dados de Solo e (e) RNA 5: sem todos os dados cartográficos qualitativos geoambientais. Fonte: Organizado pelo autor.

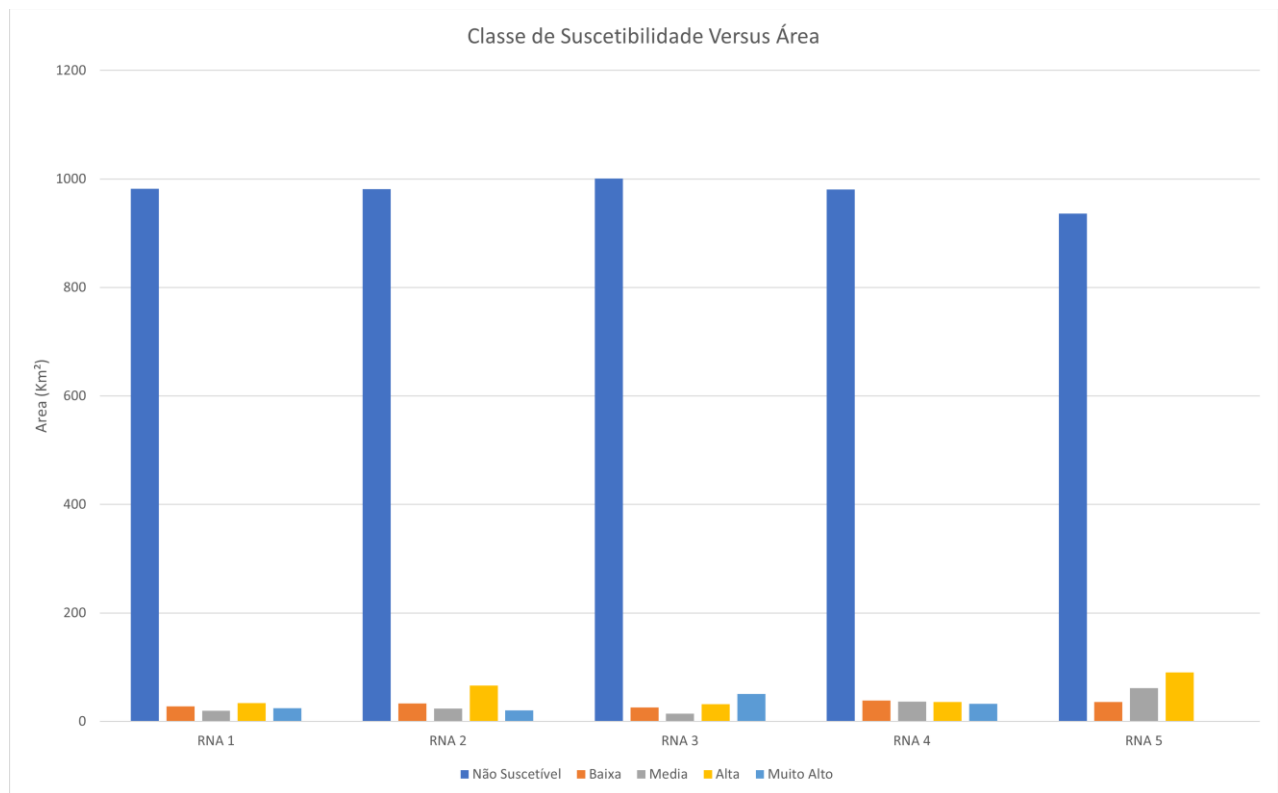


Figura 10. Área total de cada classe de suscetibilidade para as cinco simulações de RNA. Em uma análise inicial, observa-se que as áreas classificadas como não suscetíveis mantêm valores semelhantes em todas as simulações, o que pode ser atribuído às extensas regiões planas do município. As variações nos resultados são mais evidentes nas classes suscetíveis a movimentos de massa.

A simulação RNA 3, com melhores resultados de acurácia, foi feita com todas as variáveis com exceção do dado de uso e ocupação da terra. Acredita-se que esse resultado se deve à maior concentração das amostras de cicatrizes na classe Floresta do atributo de uso e ocupação da terra, conforme demonstrado na Figura 8. Em outras palavras, esse atributo está causando um viés na rede, fazendo com que ela considere que, onde há floresta, há ocorrências, reduzindo o peso da classe de declividade, por exemplo. Por essa razão, quando esse atributo é inserido na rede, reduz-se o poder de generalização da mesma para outras áreas, como por exemplo o centro urbano municipal, que possui áreas de ocorrência de deslizamento e está inserido na classe de áreas não vegetadas do uso e cobertura da terra. Para as variáveis que compõem a simulação RNA 3, foi calculado os percentuais de importância relativa ou Relative Contribution Index – RCI conforme Oliveira, Pedrollo e Castro (2015) e demonstrado na tabela 3.

Tabela 3. Importância relativa das variáveis utilizadas na simulação RNA 3.

Classe	Importância RCI
LITOLOGIA	33%
PEDOLOGIA:TEXTURA	24%
ALTITUDE	11%
DECLIVIDADE	11%
DISTANCIA HORIZONTAL ENTRE ESTRADAS	10%
DISTANCIA HORIZONTAL ENTRE LINEAMENTOS LITOSTRUTURAIS	5%

Ao compararmos os mapas de resultado produzidos pela RNA 3 e pela RNA 1, que representam simulações com o desempenho mais alto e o segundo desempenho mais alto, respectivamente, e apesar de apresentarem resultados de acurácia semelhantes, é possível observar visualmente que a RNA 1 tende a classificar de maneira mais conservadora as áreas suscetíveis nas encostas do centro urbano. Essa diferença de padrão espacial, mesmo em casos de acurácia próxima, é evidenciada em estudos anteriores, como os realizados por Oliveira et al. (2019) e Gameiro (2020). Portanto, como enfatizado por Gameiro (2020), a análise visual dos mapas derivados de modelos matemáticos empíricos, os quais se baseiam nas relações entre as variáveis de entrada e a saída esperada, desempenha um papel fundamental.

O modelo resultante da simulação RNA 4 exibe o terceiro melhor desempenho em termos de acurácia, mostrando uma tendência mais cautelosa na categorização das encostas na parte leste do município, quando comparado aos modelos gerados pelas RNAs 1 e 3. Além disso, esse modelo apresenta uma maior quantidade de áreas classificadas como suscetíveis em níveis médios, em comparação aos dois modelos mencionados anteriormente. Essa variação na classificação provavelmente se deve à exclusão, no modelo, da separação entre as classes de argissolos e neossolos litólicos. A última classe mencionada é caracterizada por solos pouco profundos encontrados em terrenos mais íngremes, os quais são diretamente associados às ocorrências predominantes na porção norte do município.

As simulações RNA 2 e RNA 5 apresentam menores acurácias do que as demais, em especial a simulação RNA 5. Apesar de apresentar valores de AUC acima de 0,8, a simulação RNA 5 exibe uma acurácia global abaixo desse limiar. Ambos os modelos foram simulados sem o arcabouço geológico, dando maior peso à DECL e DHLL. Em uma análise visual, esses resultados demonstram menor capacidade de generalização em áreas com um número menor de amostras de ocorrência, e com classificação mais conservadora em comparação com os outros modelos, com maior ênfase na classe de média suscetibilidade. Isso ressalta a importância do substrato geológico para uma ponderação mais precisa do modelo de suscetibilidade de Joinville.

Para concluir o processo de elaboração do mapa de suscetibilidade do município de Joinville, a imagem resultante da simulação RNA 3, previamente reclassificada em 5 classes de suscetibilidade, foi convertida em formato vetorial utilizando o *software* ArcGIS PRO 3.01 (ESRI, 2023). Com o intuito de ajustar os dados para uma escala de detalhamento de 1:10.000, procedeu-se à remoção dos polígonos de tamanho inferior a 10 km², ou 1 ha, e aplicou-se uma função de suavização. O resultado desse procedimento pode ser visualizado na Figura 11.

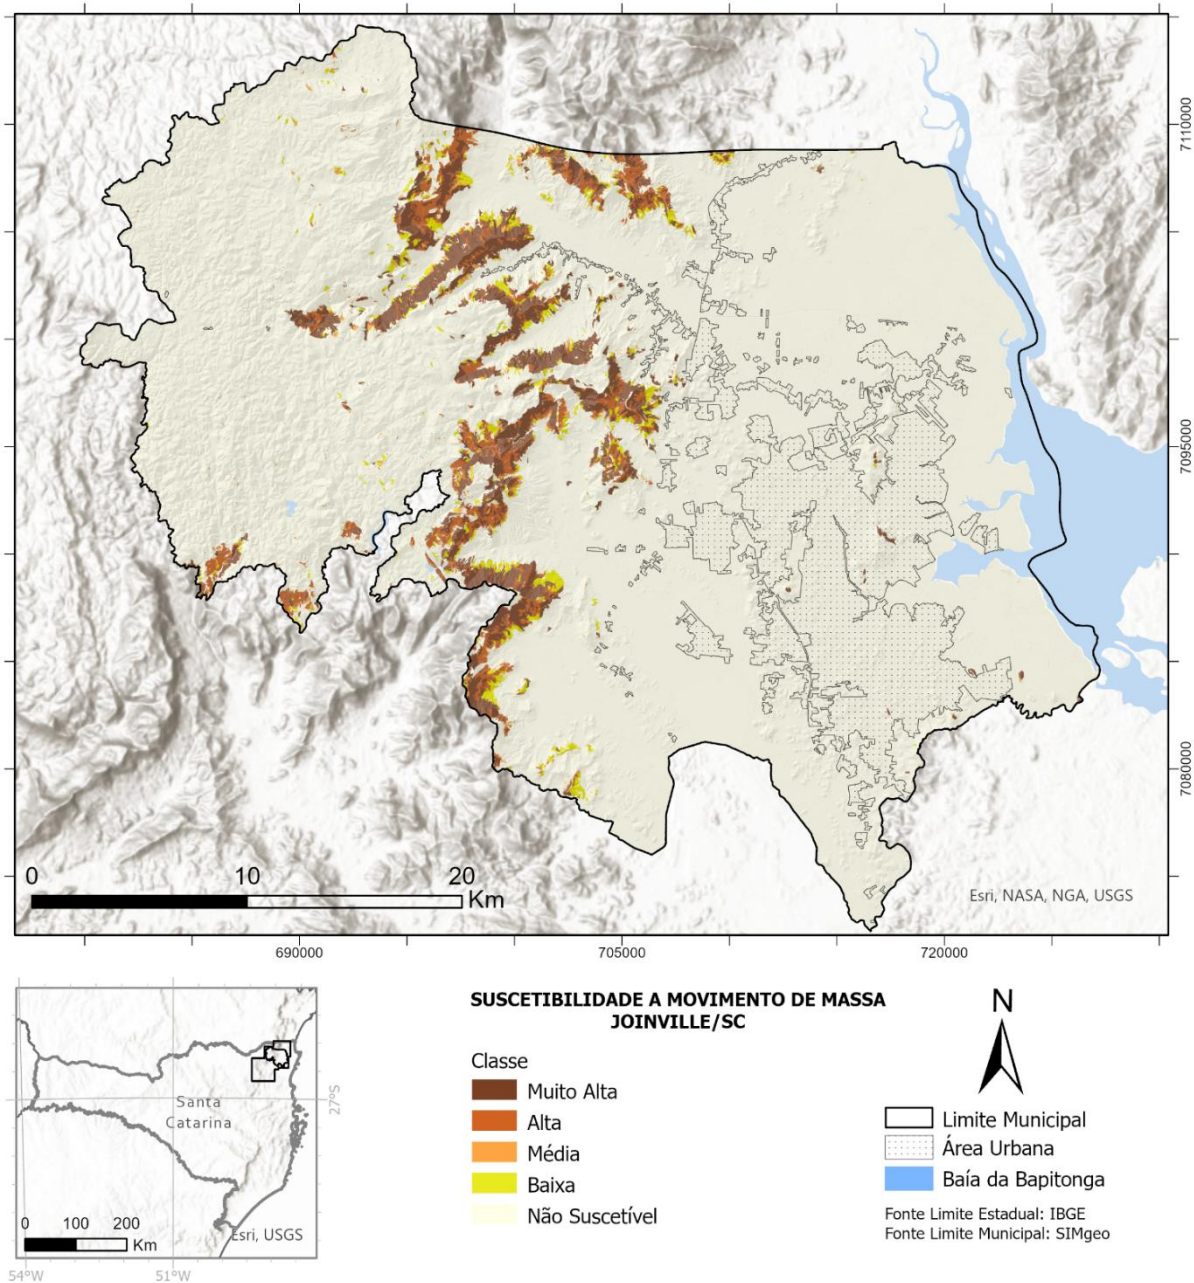


Figura 11. Mapa de suscetibilidade a movimentos de massa (SMM) do Município de Joinville-SC. Fonte: Organizado pelo autor.

4. Conclusões

Os resultados mostram que foi possível obter um modelo de SMM do município de Joinville-SC, com índices satisfatórios de acurácia global e AUC, através do uso de RNAs. De todos os modelos testados, a simulação RNA 3 apresentou melhor performance, com valores de AUC de 0,9 e ACC de 84%. Foram utilizadas 18 variáveis e 30 neurônios na camada oculta para aplicação da RNA.

A análise das variáveis morfométricas mostram uma importância sensível dos dados de DECL e OFV, indicando um condicionante de natureza geológica estrutural importante para a região. Ressalta-se aqui, que a variável DECL é possivelmente a variável explicativa do modelo aqui proposto. Os dados de DHE e DHLL corroboram esta análise e demonstram que os MM da área de estudo têm baixa indução antrópica.

Os dados qualitativos, quando utilizados devem ser escolhidos de acordo com o contexto dos MM da área de estudo. No caso deste trabalho, verificou-se que a natureza geológica do município tem importante influência na determinação da suscetibilidade do terreno. Em contrapartida os dados de Uso e Ocupação causaram um pequeno

enviesamento de rede, que reduziu levemente a acurácia e diminuiu o poder de generalização para áreas onde não há amostragem de ocorrências de MM. Ainda sobre esses, dados de melhor resolução acarretarão em melhores resultados.

Este estudo demonstra que as RNAs compõem uma ferramenta robusta para a avaliação da suscetibilidade a MM, auxiliando na prevenção de desastres e no planejamento urbano sustentável. O modelo desenvolvido para o município de Joinville mostrou-se eficaz na identificação de áreas propensas a MM, fornecendo informações para a gestão do território e redução de riscos. Entretanto, é indispensável uma validação dos dados aqui publicados em campo, para garantir sua eficácia.

Contribuições dos Autores: Redação, amostragem, preparação de dados, geoprocessamento, mapas, simulações e análises: R.R Mendonça; Script RNA para Matlab: G.G. Oliveira; Revisões: G.G. Oliveira e C. G. Tornquist.

Financiamento: Esta pesquisa não recebeu nenhum financiamento externo

Agradecimentos: Os autores agradecem o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), com apoio financeiro via Chamada CNPq N^o 09/2022 - Bolsas de Produtividade em Pesquisa - PQ, processo 311009/2022-0, e Chamada CNPq/MCTI/FNDCT N^o 18/2021 – Faixa A – Grupos Emergentes, processo 408489/2021-9

Conflito de Interesse: Os autores declaram não haver conflito de interesse.

Referências

1. ALVALÁ, R.C.S.; BARBIERI, A. Desastres Naturais. In: NOBRE C.A.; MARENGO, J.A. Mudanças climáticas em rede: um olhar interdisciplinar. São José dos Campos, SP: INCT, 2017. 608 p. ISBN 978-85-7917-463-6.
2. BITAR, O. Y. Cartas de suscetibilidade a movimentos gravitacionais de massa e inundações - 1:25.000: nota técnica explicativa. São Paulo: IPT; Brasília: CPRM, 2014. 42 p.
3. BRESSANI, L. A.; COSTA, E. A da. Mapeamento geotécnico: suscetibilidade, perigo, vulnerabilidade técnica, risco e risco instalado. In: CONGRESSO BRASILEIRO DE GEOLOGIA DE ENGENHARIA E AMBIENTAL, 14., 2013, Rio de Janeiro. Anais. Rio de Janeiro: ABGE, 2013.
4. BRAGAGNOLO, L.; DA SILVA, R. V.; GRZYBOWSKI, J. M. V. Artificial neural network ensembles applied to the mapping of landslide susceptibility. *Catena*, v. 184, p. 104240, 2020. DOI: <https://doi.org/10.1016/j.catena.2019.104240>.
5. CEMADEN - Centro Nacional de Monitoramento e Alerta de Desastres Naturais. Deslizamentos. Disponível em: <http://www2.cemaden.gov.br/deslizamentos/>. Acesso em: 15 de mar. de 2023.
6. CHEN, W., POURGHASEMI, H.R., PANAH, M., KORNEJADY, A., WANG, J., XIE, X., CAO, S. Spatial prediction of landslide susceptibility using an adaptive neuro-fuzzy inference system combined with frequency ratio, generalized additive model, and support vector machine techniques. *Geomorphology* 297, 69–85. 2017. <https://doi.org/10.1016/j.geomorph.2017.09.007>.
7. CPRM - SERVIÇO GEOLÓGICO DO BRASIL. Mapa geológico do estado de Santa Catarina. Porto Alegre: CPRM, 2014. Escala 1:500.000.
8. DELONG, E.R., DELONG, D.M., CLARKE-PEARSON, D.L. Comparing the areas under two or more correlated receiver operating characteristic curves: a nonparametric approach. *Biometrics* 44, 837–845. 1988. DOI: <https://doi.org/10.2307/2531595>
9. DOU, J.; YAMAGASHI, H.; POURGHASEMI, H.R.; YUNUS, A.P.; SONG, X.; XU, Y. & ZHU, Z. An integrated artificial neural network model for landslide susceptibility assessment of Osado Island, Japan. *Natural Hazards*, 78: 1749-1776. 2015. DOI: <https://doi.org/10.1007/s11069-015-1799-2>
10. EMAMI, S. N., YOUSEFI, S., POURGHASEMI, H. R., TAVANGAR, S., & SANTOSH, M. A comparative study on machine learning modeling for mass movement susceptibility mapping (a case study of Iran). *Bulletin of Engineering Geology and the Environment*, 79, 5291-5308. 2020. DOI: <https://doi.org/10.1007/s10064-020-01915-7>
11. Esri Inc. Arcgis PRO (versão 3.0.1). Redlands, Estados Unidos, 2023.
12. FAWCETT, T. An introduction to ROC analysis. *Pattern recognition letters*, v. 27, n. 8, p. 861-874, 2006. <https://doi.org/10.1016/j.patrec.2005.10.010>
13. GAMEIRO, S. (2020). Capacidade de Generalização e extrapolação espacial de redes neurais artificiais no mapeamento a suscetibilidade de deslizamento. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul. Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia. Porto Alegre. 85p.
14. GOMEZ, H.; KAVZOGLU, T.. Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela. *Engineering Geology*, v. 78, n. 1-2, p. 11-27, 2005. DOI: <https://doi.org/10.1016/j.enggeo.2004.10.004>
15. Google Inc. Google Earth Pro. Mountain View, California, Estados Unidos, 2023.

16. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. Disponível em: <https://cidades.ibge.gov.br/brasil/sc/joinville/panorama>. Consultado em 02 de abril de 2022.
17. Instituto Brasileiro de Geografia e Estatística. Base de Solos. 2021. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-ambientais/pedologia/10871-pedologia.html>. Acesso em: maio de 2023.
18. KAWABATA, D., BANDIBAS, J. Geomorphology Landslide susceptibility mapping using geological data, a DEM from ASTER images and an Artificial Neural Network (ANN). *Geomorphology* 113 (1-2), 97–109. 2009. <https://doi.org/10.1016/j.geomorph.2009.06>.
19. LAMBERTY, D.; KEPEL FILHO, J. L.; NORONHA, F. L. Carta de risco a movimentos de massa e inundação do município de Porto Alegre, RS: uma abordagem preliminar a partir dos dados de suscetibilidade e vulnerabilidade. In: CONGRESSO BRASILEIRO DE GEOLOGIA DE ENGENHARIA E AMBIENTAL, 15., Gramado, 2015. Anais... Gramado: ABGE, 2015. 1 CD ROM.
20. LUCCHESI, L. V.; DE OLIVEIRA, G. G.; PEDROLLO, O. C. Investigation of the influence of nonoccurrence sampling on landslide susceptibility assessment using Artificial Neural Networks. *Catena*, v. 198, p. 105067, 2021. DOI: <https://doi.org/10.1016/j.catena.2020.105067>
21. LUCCHESI, L. V.; DE OLIVEIRA, G. G.; PEDRON, F. A.; SAMUEL-ROSA, A.; DALMOLIN, R. S. D. Variação das características pedológicas e classificação taxonômica de Argissolos derivados de rochas sedimentares. *Revista Brasileira de Ciência do Solo*, v. 36, p. 1-9, 2012. <https://doi.org/10.1590/S0100-06832012000100001>
22. LUO, W., LIU, C.-C. Innovative landslide susceptibility mapping supported by geomorphon and geographical detector methods. *Landslides* 15 (3), 465–474. 2017. DOI: <https://doi.org/10.1007/s10346-017-0893-9>.
23. MAPBIOMAS. Disponível em: <http://mapbiomas.org>. Acesso em: 10 de março. 2023.
24. MINISTÉRIO DAS CIDADES. Capacitação em mapeamento e gerenciamento de risco. [S.l.]. Disponível em: <http://www.defesacivil.mg.gov.br/conteudo/arquivos/manuais/Mapeamento/mapeamento-grafica.pdf>. Acesso em: 9 set. 2013.
25. OpenStreetMap contributors. OpenStreetMap. Disponível em: <https://www.openstreetmap.org/>. Acesso em: março de 2023.
26. ODEBRECHT, Edgar et al. Acontecimentos e consequências. Atuação da ABMS e exemplo de um Laudo de Diagnóstico e sua aplicação em Joinville/SC. ANAIS COBRAE, v. 1, p. 1–8, 2017. Disponível em: http://www.adfiducia.com.br/artigos/20170301-134757_modelo-artigo-cobrae-2013----artigo---v3.pdf. Acesso em: 05 setembro de 2022.
27. OLIVEIRA, G. G.; PEDROLLO, O. C.; CASTRO, N. M.R. Simplifying artificial neural network models of river basin behaviour by an automated procedure for input variable selection. *Engineering Applications of Artificial Intelligence*, v. 40, p. 47-61, 2015.
28. OLIVEIRA, G. G.; RUIZ, L. F. C.; GUASSELLI, L. A.; HAETINGER, C. Random Forest and artificial neural networks in landslide susceptibility modeling: a case study of the Fão River Basin, Southern Brazil. *Natural Hazards*, 99, 1049, 2019. DOI: 10.1007/s11069-010-03795-x
29. PASCALE, Stefania et al. Landslide susceptibility mapping using artificial neural network in the urban area of Senise and San Costantino Albanese (Basilicata, Southern Italy). In: Computational Science and Its Applications–ICCSA 2013: 13th International Conference, Ho Chi Minh City, Vietnam, June 24-27, Proceedings, Part IV 13. Springer Berlin Heidelberg, 473-488. 2013.
30. PHAM, B.T., BUI, D.T., PRAKASH, I., DHOLAKIA, M. Rotation forest fuzzy rule-based classifier ensemble for spatial prediction of landslides using GIS. *Nat. Hazards* 83, 97–127. 2016. <https://doi.org/10.1007/s11069-016-2304-2>
31. PHAM, B.T., BUI, D.T., PRAKASH, I., NGUYEN, L.H., DHOLAKIA, M. A comparative study of sequential minimal optimization-based support vector machines, vote feature intervals, and logistic regression in landslide susceptibility assessment using GIS. *Environmental Earth Sciences* 76, 371. 2017. <https://doi.org/10.1007/s12665-017-6689-3>
32. PRADHAN, B.; LEE, S. Regional landslide susceptibility analysis using back-propagation neural network model at Cameron Highland, Malaysia. *Landslides*, v. 7, n. 1, p. 13–30, 2010. DOI: <https://doi.org/10.1007/s10346-009-0183-2>
33. QGIS Development Team. QGIS Geographic Information System (versão 3.30). 2023. Disponível em: <http://qgis.osgeo.org>.
34. QUEVEDO, R. P., OLIVEIRA, G. G., GAMEIRO, S., RUIZ, L. F. C., & GUASSELLI, L. A. Modelagem de áreas suscetíveis a movimentos de massa com redes neurais artificiais. XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2910-2913. 2019a.
35. QUEVEDO, R. P., GUASSELLI, L. A., DE OLIVEIRA, G. G., & RUIZ, L. F. C. Modelagem de Áreas Suscetíveis a Movimentos de Massa: Avaliação Comparativa De Técnicas De Amostragem, Aprendizado de Máquina e Modelos Digitais de Elevação. *Revista Geociências*, 38(3), 781-795. 2019b. <https://doi.org/10.5016/geociencias.v38i3.14019>

36. REICHENBACH, P., Rossi, M., MALAMUD, B., MIHIR, M., GUZZETTI, F. A review of statistically-based landslide susceptibility models. *Earth Sci. Rev.* 180, 60–91. 2018. DOI: <https://doi.org/10.1016/j.earscirev.2018.03.001>
37. RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, 323, 533-536, 1986. DOI: <https://doi.org/10.1038/323533a0>
38. SIG SC. Metadados Matriciais v1 [Recurso eletrônico]. Santa Catarina, Brasil: Secretaria de Estado da Administração, 2017. Disponível em: http://sigsc.sc.gov.br/1_Metadados_Matriciais_v1.pdf. Acesso em: 31 de jul. de 2023.
39. SOBREIRA, F. G.; SOUZA, L. A. de. Cartografia geotécnica aplicada ao planejamento urbano. *Revista Brasileira de Geologia de Engenharia e Ambiental*, v. 2, n. 1, p. 79-97, 2012.
40. TIEN BUI, D., TUAN, T.A., HOANG, N.-D., THANH, N.Q., NGUYEN, D.B., VAN LIEM, N., PRADHAN, B., Spatial prediction of rainfall-induced landslides for the Lao Cai area (Vietnam) using a hybrid intelligent approach of least squares support vector machines inference model and artificial bee colony optimization. *Landslides* 14 (2), 447–458. 2017. DOI: <https://doi.org/10.1007/s10346-016-0711-9>
41. ULLAH, K., WANG, Y., ZHICE FANG, Z., WANG L., RAHMAN, M. Multi-hazard susceptibility mapping based on Convolutional Neural Networks, *Geoscience Frontiers*, Volume 13, Issue 5, 2022,101425, ISSN 1674-9871. DOI: <https://doi.org/10.1016/j.gsf.2022.101425>.
42. WANG, D., PU, R., GONG, P., YANG, R. Predicting forest yield with an artificial neural network and multiple regression. *Chinese University of Hong Kong, Hong Kong*. 771–780. 1995.
43. WANG, Y.; FANG, Z.; HONG, H. Comparison of convolutional neural networks for landslide susceptibility mapping in Yanshan County, China. *Science of the total environment*, v. 666, p. 975-993, 2019. DOI: <https://doi.org/10.1016/j.scitotenv.2019.02.263>
44. WIDROW, B.; HOFF, M. E. Adaptive Switching Circuits. In: *IRE WESCON CONVENTION RECORD*, New York: IRE Part, 1960. 96– 104.
45. YAO, J., QIN, S., QIAO, S., LIU, X., ZHANG, L., & Chen, J. Application of a two-step sampling strategy based on deep neural network for landslide susceptibility mapping. *Bulletin of Engineering Geology and the Environment*, 81(4), 148. 2022. DOI: <https://doi.org/10.1007/s10064-022-02615-0>
46. ZÊZERE, J. L., PEREIRA, S., MELO, R., OLIVEIRA, S. C., & GARCIA, R. A. Mapping landslide susceptibility using data-driven methods. *Science of the total environment*, 589, 250-267. 2017. DOI: <https://doi.org/10.1016/j.scitotenv.2017.02.188>.
47. ZHU, A.X., MIAO, Y., WANG, R., ZHU, T., DENG, Y., LIU, J., HONG, H. A comparative study of an expert knowledge-based model and two data-driven models for landslide susceptibility mapping. *CATENA* 166, 317–327. 2018. DOI: <https://doi.org/10.1016/j.catena.2018.04.003>.



Esta obra está licenciada com uma Licença Creative Commons Atribuição 4.0 Internacional (<http://creativecommons.org/licenses/by/4.0/>) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuem o devido crédito pela criação original.